

Петришин Р.І.<https://orcid.org/0009-0009-2770-6656>

Івано-Франківський національний технічний університет нафти і газу

ІДЕНТИФІКАЦІЯ ЛІТОЛОГІЇ ПОРІД ЗАСОБАМИ ВЕЙВЛЕТ-АНАЛІЗУ ТА МАШИННОГО НАВЧАННЯ

У представленому дослідженні запропоновано інтегрований підхід до автоматизованої ідентифікації літології порід на вхідних каротажних даних, що дозволяє поєднувати модифіковане вейвлет-порогове знешумлення та метанавчену архітектуру. Запропонована у дослідженні методика спрямована на підвищення якості та точності процесів класифікації літологічних типів за умов обмеженого обсягу кернових і каротажних вибірок, що представляє ключові аспекти попереднього аналізу сигналу, масштабно-залежного вибору порогових значень та адаптивної оптимізації моделей. У роботі представлено та обґрунтовано імплементацію подвійної модифікованої порогової функції з верхнім і нижнім порогами та масштабною нормалізацією коефіцієнтів вейвлет-декомпозиції з метою зниження елементів реконструкції та акумуляції суттєвих геологічних ознак у високочастотних складових. Досліджено критерії вибору вейвлет-базису та представлено рекомендації стосовно оптимальних рівнів декомпозиції в межах каротажних сигналів з урахуванням властивостей неоднорідності та шуму. Процеси моделювання представлені адаптацією архітектури опрацювання візуальних даних до одновимірних послідовностей каротажу, а саме сегментації вхідних даних на вікна-патчі, багатовимірне вкладення, позиційне кодування глибини та обчислення матриць в контексті моделі глибокого навчання.

У дослідженні для подолання обмежень моделі глибокого навчання при роботі з малою вибіркою запропоновано поєднання мета-навчання та стратегій тренування, що дозволить навчати початкові параметри, що повинні максимально швидко адаптуватися до нових геологічних умов, що постійно змінюються за мінімальної кількості зразків. Крім того, рекомендовано використовувати епізодичне формування задач і метод статистичної оцінки математичних інтегралів шляхом вибірки на основі зв'язувальних коефіцієнтів, що компенсується різницею між цільовими та пропозиційними розподілами для забезпечення рівномірного представлення класів і зниження варіативності навчання.

У роботі проаналізовано процедуру навчання та валідації у вигляді формування наборів підтримки та запитів, внутрішні та зовнішні цикли оптимізації з різними швидкостями навчання, приведено оцінку через набір мета-тестування та накопичення прогнозу за допомогою поєднання моделей з експоненціальною нормалізацією як способу перетворення вихідних значень моделей у ймовірності перед початком порівняння, аналізу, комбінування та побудови кінцевого прогнозу. Запропонована послідовність поєднує вейвлетну передобробку та мета-адаптацію для досягнення економічно ефективного прогнозування літологічних процесів при дефіциті кернових даних, що дозволить забезпечити баланс між співвідношенням сигналу та шуму й середньоквадратичною помилкою реконструкції.

Практична цінність запропонованого підходу полягає в підвищенні точності класифікації, зменшенні ризиків буріння та оптимізації ресурсозатрат розвідки вуглеводнів. Крім того, окреслено напрямки подальшого вдосконалення на основі автоматичного вибору порогів за шкалою, оптимізація вейвлет-базису через крос-валідацію та розширення комбінованих стратегій для підвищення стабільності та узагальнення моделі.

Ключові слова: архітектура, вейвлет-аналіз, машинне навчання, автоматизація, мета-оптимізація, мета-навчання, прогнозування, моделі, літологія, каротаж, геологічні ознаки.

Постановка проблеми. Сучасні дослідження в геології та розвідці нафтових і газових покладів характеризуються чітким прогнозування літології. Літологічна класифікація, що базується на

ретельному та диференційованому аналізу каротажних даних, є базовим елементом у виявленні, аналізі, оцінці та подальшій експлуатації нафтових і газових покладів. Процеси аналізу та визна-



чення залягання, складу та характеристик літологічних порід не лише впливають на ефективність процесів видобування, але й передбачають можливість оптимізації стратегії розробки, що, в свою чергу, знижує ризики та витрати на сам процес. Максимально чітка та висока точність прогнозування залягання покладів дозволяє підвищити ефективності розвідки, що, в свою чергу, є максимально важливим в умовах обмеженості ресурсів.

Хоча багато традиційних методів, що застосовуються в геологічній розвідці, зіштовхуються з суттєвими проблемами через потужне шумове забруднення даних, обмежену кількість зразків та складність геологічних структур. Самі процеси видобування та виокремлення зразків керну є дорогими та витратними, що зумовлює потребу в отриманні точних даних на етапі проектування. Якщо вести мову про незначні вибірки геологічних даних, що досить часто спостерігається, то це може призводити до недостатньої ефективності використання моделей машинного навчання, так як вони не можуть адекватно навчатися на обмежених обсягах даних, а особливо на якісних та точних даних. Крім того, більшість базових алгоритмів машинного навчання вимагають великої кількості даних для досягнення стабільних результатів. І, відповідно, у ситуаціях, де кількість та якість наявних даних є обмеженою, традиційні підходи можуть бути ризикованими в контексті максимального перенавчання та низького рівня узагальнення. Тому досить важливим є можливість досліджувати та аналізувати суттєво нові методи та підходи, що дозволять використовувати малі вибірки даних в разі ефективніше.

Одним із новітніх рішень, що має потенціал для суттєвого покращення точності процесів геологічного моделювання, є інтеграція вейвлет-аналізу з алгоритмами машинного навчання. Вейвлет-порогові алгоритми здатні ефективно усувати шум з даних каротажу, що суттєво покращує якість прогнозування літології. Згадані алгоритми займають важливе місце в процесі попередньої обробки даних і можуть в значній мірі підвищити коректність подальшої інтерпретації. Однак значно менше наукових досліджень присвячено інтеграції вейвлет-аналізу з сучасними методами глибокого навчання на основі моделей опрацювання візуальних даних, що створює значні сучасні можливості для покращення якості літологічних прогнозів.

Усунення шумів, отриманого за доступним методом вейвлет-аналізу, є критично важливим, оскільки якість вибору порогових значень

прямо вплине на результат. Надмірне або недостатнє фільтрування даних може призвести до втрати важливої інформації, критично важливої для правильного визначення літологічної структури. Це підкреслює необхідність дослідження взаємозв'язку між вибором вейвлет-базису, порогового значення та ефективністю алгоритмів машинного навчання. Враховуючи ці фактори дослідження зосереджується на пошуку оптимальних умов для комбінування вейвлет-аналізу з мета-навчанням.

У цьому контексті мета-навчання, як спеціалізований підхід, що фокусується на швидкій адаптації моделей до нових завдань, стає перспективним рішенням для проблеми недостатньої вибірки даних. Методики, що впливають із навчання з малими вибірками, забезпечать основу для розробки моделей, здатних успішно справлятися зі складними літологічними структурами, маючи доступ до неповних та ненадійних даних.

Дослідження мета-навчання в контексті літологічного прогнозування дозволяє вивчити, як моделі можуть використовувати обмежені дані з різних геологічних контекстів для навчання на основі спільних характеристик та закономірностей. Методика мета-навчання надає можливість створювати адаптивні моделі, що можуть швидко переналаштовуватись для нових завдань, використовуючи інформацію з раніше оброблених наборів даних. Таким чином, у разі недостатності даних для навчання літологічних моделей, можливо налаштувати їх для більшої продуктивності, орієнтуючись на здобуті знання з подібних геологічних завдань.

Однією з основних цілей цього дослідження є розробка моделі, що поєднує у собі механізми мета-навчання та архітектуру для досягнення оптимізації точності літологічного прогнозування. Зокрема, досліджується, як стратегії оновлення параметрів, що використовуються в мета-навчанні, можуть підвищувати продуктивність моделей під час обробки даних каротажу. При цьому акцентується увага на важливості ефективного використання наборів підтримки та запитів, що забезпечують зворотний зв'язок для моделі, що веде до її адаптації до нових сценаріїв.

Це дослідження також вирішуватиме питання, пов'язані з ускладненнями, викликаними різноманітними геологічними умовами. Наприклад, це стосується специфічних проблем, що виникають через неоднорідність підземних літологій, складності структури пластів та їх уразливість до розривів у даних. Ці фактори можуть призводити до

поганої інтерпретації результатів прогнозування, що є критично важливим у процесі прийняття рішень для подальшого розв'язання технологічних проблем.

На фоновій основі велике значення має аналіз передумов для вибору оптимальних вейвлет-базисів і порогових функцій у рамках реалізації вейвлет-аналізу. Виконуване дослідження за темою виявить, яку роль відіграють різні вейвлет-базиси в корекції та деталізації літологічних даних, і які з них проявляють найкращі результати при зменшенні шуму в даних. Визначення оптимізації цих параметрів, а також подальша інтеграція з алгоритмами машинного навчання, стає критичним етапом для підвищення точності прогнозування. На шляху до досягнення поставлених цілей, дане дослідження має намір внести значний внесок у розвиток технологій, здатних адаптувати та оптимізувати моделі для умов дефіциту даних. У результаті успішної реалізації запропонованих методів, значно підвищиться пристосованість та точність моделей для прогнозування літології.

Таким чином це дослідження акцентує увагу на необхідності поєднання вейвлет-аналізу з сучасними підходами машинного навчання, що здатні ефективно працювати в умовах обмежених даних. Перспективи розвитку таких гібридних методик відкривають нові горизонти для геологічної розвідки, підвищуючи точність прогнозів та зменшуючи ризики, пов'язані з бурінням, і в результаті сприяють більш раціональному використанню природних ресурсів.

Аналіз останніх досліджень і публікацій. У рамках аналізу останніх досліджень та публікацій щодо питань автоматизованої ідентифікації літології виділено актуальні підходи до класифікації даних [1,10]. Зокрема, у дослідженні [1] запропоновано удосконалений підхід, що дозволяє екстрагувати складний семантичний інформаційний контент з послідовностей, а також адресувати проблему неможливості захоплення контекстуальної інформації на рівні слів. Дослідження підтверджує важливість конволюції для захоплення граматичної інформації n-грам, що може бути паралельно застосоване і для задач літологічної ідентифікації. Також акцентовано увагу на тому, що використання численних методів, включно з комбінуванням мета-навчання та епізодичними стратегіями тренування, дозволяє моделям швидко адаптуватися до нових умов, що є критично важливим для досягнення точної ідентифікації літології в умовах обмежених даних. Це створює основу для подальших розробок, що

можуть суттєво поліпшити якість та точність прогнозування літологічних структур у нафтових і газових розвідках.

У науковій праці [2] особливу увагу приділено дослідженню ефективності багатосарового перцептрона та лінійної регресії у контексті статистичних моделей, де увага акцентується на якості прогнозування та оцінки, а також на стійкості до відхилень від основних гіпотез в контексті припущень у вигляді нормальності, гомоскедастичності та незалежності помилок, що застосовуються для забезпечення коректності висновків. У дослідженні зазначається, що багатосаровий перцептрон може забезпечити стабільність прогнозів, що, відповідно, є критично важливим у поточному дослідженні літологічної ідентифікації. Це узгоджується з пропонованим у цьому дослідженні підходом, що передбачає модифіковане вейвлет-порогове знешумлення у комбінації з мета-навченою архітектурою. У дослідженні автори використовують методи, що дозволяють адаптувати моделі до нових умов, що підкреслює важливість гнучкості та стабільності у процесах ідентифікації літології в умовах обмежених даних. Важливість та необхідність використання нових підходів до моделювання послідовності в досліджуваній архітектурі особливо підходить для обробки даних, пов'язаних з ідентифікацією літології та є досить важливим аспектом у дослідженні. Науковці аналізують ефективність кодування позицій, що забезпечує важливу інформацію для моделювання залежностей між елементами на різних позиціях у послідовностях.

Аналізований метод обертового позиційного вбудовування [3] дозволяє інтегрувати абсолютні позиційні дані за допомогою обертових матриць та одночасно враховує явні відносні залежності позицій в проєктованому механізмі. Це дозволяє досягнути важливих характеристик в контексті гнучкості довжини послідовності, зниження залежності між токенами при збільшенні відносних відстаней та покращення роботи лінійних характеристик з кодуванням відносних позицій. Запропонований метод відкриває нові перспективи для підвищення точності та ефективності класифікації літологічних типів, зокрема у контексті використання вейвлет-аналізу та створює основу для подальшого вдосконалення систем автоматизованої обробки каротажних даних, що робить можливим суттєво якісно покращити результати в розвідці нафтових і газових покладів.

Створення систем мета-навчання, що демонструють значний успіх у виконанні багатьох

завдань, є досить актуальним в багатьох галузях. Однак питання створення стабільної та неупередженої мета-моделі залишається суттєвою проблемою для дослідників. У науковому дослідженні [4] стверджується, що початкова модель мета-системи може бути занадто орієнтована на існуючі завдання, що ускладнює її адаптацію до нових та незнайомих ситуацій. Тому для вирішення цієї проблеми пропонується універсальний метод мета-навчання, спрямований на формування неупередженої моделі, що зможе ефективно та якісно реагувати на різноманітні завдання ще до адаптації початкової моделі до нових проблем. Сутністю пропонованого дослідження є метою навчання мета-ваг, суть якого полягає у мінімізації нерівності результатів між різними навчальними завданнями. Використання підходу навчання «від початку до кінця», що дозволяє оптимізувати ваги та ініціалізувати структуру нейронної мережі, є якраз доречним. Тому розробка різних методів вимірювання ваг, що перевіряють ефективність різних стратегій навчання в контексті поліпшення алгоритму мета-навчання, незалежного від конкретної моделі, є актуальною та першочерговою для такого роду досліджень. Це підтверджує важливість адаптації сучасних алгоритмів у контексті ідентифікації літології, що може суттєво підвищити точність автоматизованих систем обробки каротажних даних у геолого-розвідувальних процесах, аналізуючи та оптимізуючи результати досліджень.

Аналізу питань адаптивної обробки сигналів, зосереджуючи увагу на застосуванні мультишарового перцептрона у системах навчання, приділено суттєву увагу у дослідженнях [5] де зазначається, що ефективність мультишарового перцептрона значною мірою залежить від оптимізації параметрів навчання. В результаті запропоновано вдосконалений алгоритм навчання, що базується на методі зворотного поширення помилки. Цей алгоритм, що є формою стохастичного градієнтного спуску, контролюється власними розподілами матриці кореляції вхідного сигналу. Результати експериментів підтверджують, що використання мультишарового перцептрона робить його перспективним рішенням для задач моделювання та ідентифікації літології, особливо в умовах обмежених даних.

Інше дослідження [6] характеризується аналізом гібридної моделі, що поєднує багатошаровий перцептрон і згорткову нейронну мережу для прогнозування параметрів буріння. Виокремлені ознаки у вигляді глибини буріння, крутного

моменту та струму, результативно використані для розрахунку тиску в процесі буріння, що дозволило суттєво підвищити продуктивність та точність прогнозів. Запропонований підхід [6] має значний потенціал для застосування в автоматизованих системах обробки даних, що, в свою чергу, може сприяти покращенню ідентифікації літології у процесах геологічної розвідки.

Інше дослідження [7] акцентує увагу на використанні моделей машинного навчання для досягнення точних оцінок пористості та проникності під час бурових операцій, що базується на розробці та використанні методики прогнозування петрофізичних властивостей на основі параметрів буріння. Як результат, представлені у дослідженні [7] базові принципи можуть бути інтегровані в процес ідентифікації літології, що ґрунтується на вейвлет-аналізі і методах машинного навчання, підвищуючи точність та ефективність даних досліджень, що відкриває нові можливості для автоматизації обробки каротажних даних.

Дослідження підходів до прогнозування індексу швидкості буріння з використанням гібридних моделей машинного навчання є досить актуальним, особливо щодо аналізу процесу ідентифікації літології порід на основі вейвлет-аналізу та машинного навчання. Результати дослідження [8] свідчать, що інтеграція різних алгоритмів значно підвищує точність прогнозів, що є важливим аспектом для оптимізації бурових процесів.

Аналіз питання швидкого навчання складних задач за допомогою методів мета-навчання, що базуються на онлайн-оптимізації, і які пов'язані зі стабільністю навчання та ефективністю адаптації моделей до нових умов, представлені у [9] можуть бути тісно пов'язані з дослідженнями щодо ідентифікації літології порід через вейвлет-аналіз та машинне навчання, оскільки адаптація сучасних методів мета-навчання може суттєво підвищити точність автоматизованої обробки каротажних даних і, відповідно, покращити процеси розвідки вуглеводнів. Застосування алгоритмів вейвлет-порогового знешумлення [10] в поєднанні з мета-навчанням може суттєво підвищити ефективність класифікації літології на основі даних каротажу з обмеженою вибіркою.

Постановка завдання. Метою статті є розробка нового підходу до ідентифікації літології порід, заснованого на вейвлет-аналізі та методах машинного навчання, що включає використання пропонованої моделі у поєднанні з мета-навчанням. Такий підхід дозволить досягти високої точності прогнозування літологічних характеристик

на основі використання обмежених каротажних даних, що дозволить суттєво зменшити ризики та витрати в процесах геологічної розвідки. Дослідження також акцентує увагу на технології автоматизованої обробки даних, що дозволить удосконалити класифікацію літологічних типів та підвищити ефективність процесів розвідки нафти і газу.

Виклад основного матеріалу. Першочерговим завданням нафторозвідки є визначення розташування, розподілу і характеристик нафтових і газових покладів. Точне прогнозування літології може допомогти визначити потенційні поклади вуглеводнів, визначити напрямок буріння та стратегії розробки, максимізуючи ефективність розвідки та видобуток вуглеводнів. Прогнозування літології також допомагає оцінити ризики буріння уникаючи типових нештатних ситуацій та забезпечуючи плавне буріння. Ефективно використовуючи результати прогнозування літології дозволяє зменшити непотрібні ризики розвідки та неефективну втрату ресурсів максимізуючи ефективність розвідки та видобування вуглеводнів. Буріння та відбір керн є дорогішими та складними процесами, а отримання більшої кількості даних керну потребує більше часу, ресурсів та витрат. Таким чином, прогнозування літології каротажу з використанням невеликої кількості даних зразків керну може бути економічно ефективним. Машинне навчання значно підвищує точність і ефективність прогнозування літології забезпечуючи помітний технологічний стрибок у геологічному аналізі. Ця інтеграція надає геологам удосконалені інструменти для виконання досліджень пришвидшуючи процеси розвідки нафти і газу. Отримання даних буріння часто обмежене різними факторами, такими як геологічні умови та економічні витрати. Через високу вартість і тривалі інженерні цикли, пов'язані з бурінням, отримання даних буріння зазвичай обмежене часом і ресурсами, що призводить до дефіциту зразків даних. Складність геологічних родовищ суттєво впливає на невизначеність даних. Такі фактори, як складність структур пластів, різноманітність потоку підземних вод і неоднорідність підземної літології, суттєво ускладнюють інтерпретацію та аналіз даних буріння.

Дані невеликої вибірки стосуються наборів даних із відносно невеликою кількістю вибірок у машинному навчанні та статистиці. Як правило, невеликі вибіркові набори даних містять набагато менше зразків, ніж функцій, що може призвести до проблем із використанням тради-

ційних алгоритмів машинного навчання. Проблема з малими вибірковими даними полягає в тому, що через обмежену кількість вибірок моделям важко засвоїти достатньо узагальнені шаблони, що робить їх схильними до впливу шуму та випадковості під час навчання. Навчання на основі даних невеликої вибірки називається навчанням невеликої вибірки, це спеціалізований підхід машинного навчання, спрямований на отримання максимальної інформації з обмежених вибірок. Методи навчання невеликої вибірки включають мета-навчання, навчання передачі, розширення даних тощо, спрямовані на покращення продуктивності моделі на даних невеликої вибірки шляхом використання інформації з інших завдань чи наборів даних або збільшення різноманітності та кількості вибірки. Традиційні алгоритми машинного навчання зазвичай мають певну складність моделі та часто вимагають великих обсягів даних для навчання, щоб ефективно фіксувати складні шаблони та структури в даних. Якщо розмір вибірки занадто малий, моделі можуть страждати від недостатнього підбору, що призведе до зниження продуктивності та здатності до узагальнення. У контексті прогнозування літології каротажу кілька тисяч точок даних можна вважати невеликими вибірковими даними, оскільки, відносно складності завдання прогнозування та моделі, такий масштаб даних все ще може бути недостатнім для повного охоплення всіх можливих сценаріїв і моделей. Прогнозування літології за допомогою каротажу зазвичай включає різні геологічні особливості та складні стратиграфічні структури, що вимагає від моделей високої здатності до узагальнення, щоб робити точні прогнози за різних геологічних умов. Крім того, дані каротажу можуть бути піддані шуму та невизначеності, що вимагає більше даних для точного фіксування взаємозв'язків між геологічними об'єктами. У цьому сценарії кілька тисяч точок даних все ще можуть не відповідати вимогам до навчання моделі, тому вони вважаються даними невеликої вибірки. Причина, по якій традиційні моделі машинного навчання потребують сотень тисяч або навіть мільйонів точок даних для навчання, в той час як підходи, засновані на мета-навчанні, можуть потребувати лише кількох тисяч навчальних даних, головним чином полягає в різних робочих принципах і стратегіях навчання.

Традиційні методи машинного навчання, такі як опорні векторні машини та випадкові ліси, вимагають великих наборів даних для ефективного

розуміння геологічної складності та підвищення точності прогнозів. Ці моделі є незамінними для надійності аналізу даних забезпечуючи стабільну роботу в різних геологічних умовах. Через складність геологічних систем і високу мінливість даних каротажу традиційні моделі машинного навчання вимагають великих обсягів даних для забезпечення узагальнення та точності моделі. І навпаки, підходи, засновані на мета-навчанні, приймають іншу парадигму навчання. Мета-навчання має на меті покращити здатність узагальнення моделі шляхом навчання на невеликій кількості зразків із різних завдань. У прогнозуванні літології каротажу методи мета-навчання можуть використовувати невелику кількість навчальних даних з різних геологічних регіонів або типів літології, щоб вивчити загальні правила та закономірності між геологічними особливостями та даними каротажу. Таким чином, методи мета-навчання можуть створювати прогнозні моделі з сильною здатністю до узагальнення, використовуючи відносно менше навчальних даних.

Моделі глибокого навчання базуються на архітектурі обробки візуальних даних, де їх ядром є механізм само уважності (*Self-Attention Mechanism*). Для реєстрації даних архітектури спочатку розділяють вхідне зображення або послідовність на кілька фрагментів фіксованого розміру, які потім розглядаються як дані послідовності та обробляються цією архітектурою. Механізм самоконтролю фіксує зв'язки між різними патчами (*patches*) в глобальному масштабі, дозволяючи архітектурі краще розуміти глобальну інформацію в даних. Для завдань прогнозування літології, що включають складні геологічні структури або вимагають розгляду віддалених особливостей, можливість глобального сприйняття архітектури опрацювання візуальних даних дає змогу фіксувати зв'язки між складними об'єктами, зберігаючи детальну інформацію. Механізм самоконтролю архітектури природним чином підходить для визначення довгострокових залежностей. Архітектура опрацювання візуальних даних, розділяючи дані на патчі та використовуючи самоуважність для аналізу глобальних зв'язків між кожним патчем, здатна досягати глобального вилучення функцій. Оскільки кожен патч може взаємодіяти з усіма іншими, архітектура комплексно екстрагує глобальну інформацію з даних, що робить її ефективною у сценаріях, де розуміння глобальної інформації має вирішальне значення для прогнозування літології, особливо в складних геологічних структурах.

Розглянемо модель мета-архітектури опрацювання візуальних даних для класифікації літології порід, що поєднує мета-навчання та зазначену архітектуру для вирішення проблем у прогнозуванні літології порід свердловин. Застосування моделі для даних каротажу малої вибірки пропонує декілька переваг. Стратегії оновлення параметрів моделі, що зазвичай використовуються в мета-навчанні, дозволяють моделі ефективніше вивчати подібності та відмінності між завданнями. Для запропонованої моделі мета-навчання може допомогти у виявленні конкретних особливостей та моделей у сфері геологічної розвідки, тим самим покращуючи її продуктивність у задачах розпізнавання літології порід. Розбиття наборів підтримки та наборів запитів, що зазвичай використовуються у мета-навчанні, може ефективно використовувати дані та допомогти моделі вивчати зв'язки між завданнями. У мета-навчанні для літології набір підтримки готує модель для адаптації завдання, а набір запитів – перевіряє рівень її узагальнення новими даними. Це навчання підвищує адаптивність моделі до різноманітних геологічних даних.

Що стосується вейвлет-порогового значення, то у вейвлет-пороговому усуненні шуму початковим кроком є виконання вейвлет-перетворення з багатомасштабним розкладанням вимірних даних каротажу для отримання коефіцієнтів у різних масштабах. Кожен масштабний коефіцієнт порівнюється з попередньо вибраним порогом; коефіцієнти нижче порогового значення відкидаються, а коефіцієнти вище порогового значення – зберігаються. Згодом збережені коефіцієнти в кожному масштабі реконструюються, щоб отримати дані каротажу після знешумлення. Якість усунення шумів залежить насамперед від трьох аспектів: вибору вейвлет-базисної функції, кількості рівнів розкладання та методу, який використовується для встановлення порогових значень високочастотних коефіцієнтів після розкладання. У процесі вейвлет-усунення шуму вибір порогової функції є вирішальним, і найбільш широко використовувані методи наразі включають жорстке та м'яке порогове визначення.

При використанні жорсткого порогового методу для обробки вейвлет-коефіцієнтів, коефіцієнти, абсолютні значення яких перевищують фіксоване порогове значення, зберігаються на пороговому рівні; інакше вони встановлюються як нуль. Хоча метод жорсткого порогового визначення може покращити відношення сигнал/шум, під час вейвлет-реконструкції розрив функції

жорсткого порогового значення на пороговому рівні може призвести до коливань у реконструйованих даних каротажу свердловин. Це явище спостерігається при обробці даних каротажу свердловин, що характеризується гострими краями або коливаннями в реконструйованих даних каротажу свердловин, які є найбільш помітними при стрибках або межах даних каротажу свердловин. Воно в основному спричинене розривом, який вносить метод жорсткого порогового значення, коли коефіцієнти різко скорочуються до нуля на пороговому рівні замість плавного переходу до нуля. Цей розрив генерує високочастотні компоненти під час процесу реконструкції, що призводить до коливань у даних каротажу. Щоб пом'якшити такий феномен метод м'якого порогового визначення можна використовувати як альтернативу жорсткому пороговому значенню. Метод м'якого порогового визначення забезпечує плавний перехід на пороговому рівні, зменшуючи коливання в реконструйованих даних каротажу свердловин. Крім того такий вплив можна пом'якшити, покращивши порогову функцію або застосувавши альтернативні методи усунення шумів для досягнення більш плавних і точних результатів реконструкції:

$$\bar{\omega}_{j,k} = \begin{cases} \omega_{j,k}, & |\omega_{j,k}| \geq \lambda, \\ 0, & |\omega_{j,k}| < \lambda. \end{cases} \quad (1)$$

де $\bar{\omega}_{j,k} \approx \omega_{j,k}$ – вейвлет-базисна функція, λ – порогове значення.

Метод м'якого порогового визначення є поширеною технікою для вейвлет-порогового усунення шумів. Під час обробки вейвлет-коефіцієнтів, якщо абсолютне значення коефіцієнта перевищує фіксоване порогове значення, абсолютне значення коефіцієнта зберігається; інакше коефіцієнт встановлюється рівним нулю. Порівняно з методом жорсткого порогового визначення, метод м'якого порогового визначення вводить плавний перехід, що призводить до більш плавних знешумлених даних каротажу свердловин, хоча зазвичай із нижчим співвідношенням сигнал/шум. Однак метод м'якого порогового визначення також має деякі недоліки. Однією з головних проблем є те, що реконструйовані дані каротажу часто мають більшу середньоквадратичну помилку. Це пояснюється тим, що метод м'якого порогового значення віднімає константу з усіх розкладених вейвлет-коефіцієнтів, у результаті чого утворюється постійна різниця, яка збільшує загальну флуктуацію даних реконструйованого каротажу

свердловин. При знешумленні даних каротажу свердловин метод м'якого порогового значення може призвести до певних проблем. Через ефект згладжування, застосований до вейвлет-коефіцієнтів, результати можуть надмірно згладжувати деталі в пікових точках, потенційно спричиняючи втрату деяких важливих характеристик у даних каротажу свердловин. Зокрема, коли йдеться про такі аномалії, як розриви проводів, метод м'якого порогового значення може надмірно згладити дані, що призведе до втрати детальної інформації та вплине на точність реконструйованих даних каротажу свердловин. Щоб вирішити проблеми, які може спричинити метод м'якого порогового усунення, може бути корисним визначення потенційної гібридизації з іншими методами усунення шумів або удосконалення функції м'якого порогового усунення, щоб знайти баланс між ефективністю усунення шумів і точністю реконструкції. Крім того, налаштування параметрів м'якого порогового відповідно до конкретної ситуації може призвести до кращих результатів усунення шумів.

$$\bar{\omega}_{j,k} = \begin{cases} \operatorname{sgn}(\omega_{j,k})|\omega_{j,k} - \lambda|, & |\omega_{j,k}| \geq \lambda, \\ 0, & |\omega_{j,k}| < \lambda. \end{cases} \quad (2)$$

Тому використовується модифікована подвійна порогова функція з таким виразом:

$$\bar{\omega}_{j,k} = \begin{cases} \operatorname{sgn}(\omega_{j,k})|\omega_{j,k} - \lambda_1 e^{2\lambda_1 - \lambda_2 - |\omega_{j,k}|}|, & |\omega_{j,k}| \geq \lambda_2, \\ \operatorname{sgn}(\omega_{j,k})|\omega_{j,k} - \lambda_1 e^{2\lambda_1 - 2|\omega_{j,k}|}|, & \lambda_1 < |\omega_{j,k}| < \lambda_2, \\ 0, & |\omega_{j,k}| < \lambda_1, \end{cases} \quad (3)$$

де λ_1 – верхній поріг, λ_2 – нижній поріг, $\lambda_2 = k\lambda_1$. Якщо k більше 1 і $\omega_{j,1}$ має тенденцію до нескінченного зростання, вейвлет-коефіцієнт $\bar{\omega}_{j,k} \approx \omega_{j,k}$, що може полегшити проблему коливань при реконструкції даних каротажу свердловин. Вибір порогового значення також має вирішальне значення, оскільки як занадто великі, так і занадто малі значення можуть вплинути на якість усунення шумів. Надмірно великий поріг може відфільтрувати корисну інформацію з даних каротажу свердловин, тоді як надто малий поріг може не забезпечити ефективного видалення шуму. Традиційним методом вибору порогов є $\lambda = \sigma_j \sqrt{2 \ln N}$, де поріг фіксується після визначення на основі кількості точок вибірки N . Однак вейвлет-коефіцієнти даних каротажу свердловини зменшуються зі збільшенням масштабу розкладання, і фіксований поріг не може адекватно зберегти інформацію при різних

змінах даних каротажу свердловини. Тому для вибору порогового значення використовується метод, який дозволяє змінювати порогове значення залежно від масштабу розкладання:

$$\lambda = \sigma_j \sqrt{2 \ln N} / \ln(j+1), \quad (4)$$

де σ_j – стандартне відхилення, j – шкала розкладання. У вейвлет-декомпозиції вибір відповідного базису вейвлетів є вирішальним для отримання точних результатів усунення шумів. Загальні критерії вибору вейвлет-базису включають автокореляцію, симетрію, ортогональність, регулярність. При вирішенні конкретних завдань слід вибирати найбільш прийнятний вейвлет-базис на основі характеристик даних каротажу свердловин і вимог до обробки. Для певних застосувань, таких як дані каротажу свердловин, базиси вейвлетів Nd можуть бути непридатними через їх асиметрію, яка може викликати помилки. Крім того, вейвлет може бути розривним у часовій області та може не забезпечувати плавних результатів, що призводить до неоптимальних результатів обробки. Натомість, вейвлет-базиси з класу $symN$ демонструють добру симетрію та можуть краще зберігати характеристики даних каротажу. За допомогою експериментів і валідації можна додатково визначити оптимальний базис вейвлетів і рівні декомпозиції для досягнення більш точних і надійних ефектів усунення шумів. Тому в процесі вейвлет-усунення шумів раціональний вибір вейвлет-базису є одним із ключових кроків для забезпечення ефективної обробки.

Аналізована архітектура, що на основі використання методу опрацювання зображень дозволяє гарантувати точність та швидкість у аналізі зображень, і як фундаментальна основа навчання, широко застосовувалася не лише для обробки даних зображення, але й для обробки одновимірних сигналів каротажу свердловин, позначених як вхід X , що призвело до зміни вхідної структури моделі. Досліджувана архітектура, в основному, базується на модулях у вигляді компонентів самої архітектури, що дозволяють моделі акцентувати увагу на різних частинах вхідних даних одночасно. Один з модулів дозволяє моделі швидко фіксувати внутрішні особливості даних, виконуючи паралельні обчислення, ефективно вилучаючи з даних інформацію про локальні та глобальні характеристики. У той же час інший модуль використовується для виконання нелінійних перетворень і комбінацій функцій, що ще більше підвищує репрезентативну здатність моделі. Цей дизайн моделі, заснований на аналізованій архітектурі,

дозволяє демонструвати ефективну продуктивність під час опрацювання послідовних даних, таких як одновимірні сигнали каротажу свердловин, надаючи потужні інструменти аналізу даних для геологічної розвідки, розробки вуглеводневих ресурсів тощо.

У задачах літологічного прогнозування адаптація досліджуваної архітектури передбачає кілька коригувань його базової структури та робочого процесу для підвищення його продуктивності при роботі з геологічними даними. На відміну від даних зображень, дані послідовності каротажу зазвичай складаються з неперервних послідовностей часу або глибини. По-перше, ці послідовності перетворюються у формат, придатний для обробки цією архітектурою, наприклад, сегментування даних послідовності на вікна фіксованої довжини (схожі на патчі в даних зображення), причому кожне вікно служить окремим блоком введення. Потім кожне вікно даних журналу вбудовується у багатовимірний простір, подібно до того, як фрагменти зображень вбудовуються у багатовимірні вектори. Цей крок допомагає моделі охопити локальні особливості в межах послідовності. У аналізованій архітектурі позиційне кодування інформує модель позицій точок даних, що має вирішальне значення для інтерпретації послідовностей каротажу свердловин. Його механізм самоконтролю дозволяє глобально розуміти літологічні особливості, причому пропонуються різноманітні аналітичні перспективи, що збагачує розпізнавання геологічних особливостей.

У досліджуваній архітектурі дані каротажу сегментуються на фрагменти фіксованої довжини, кожен з яких містить точки даних, перетворені на вектори великої розмірності за допомогою лінійних перетворень. Ці вектори, вбудовані за допомогою позиційного кодування, служать вхідними даними для механізму самоуважності, дозволяючи моделі фіксувати реляційну динаміку послідовності. Позиційне кодування, критичне для підтримки безперервності послідовності, може бути визначено заздалегідь або засвоєно, підвищуючи здатність моделі інтерпретувати послідовні дані. Потім механізм самоконтролю обробляє ці вектори, щоб ідентифікувати глобальні зв'язки та динамічно коригувати ваги ознак, сприяючи розпізнаванню складних шаблонів і залежностей у послідовності.

У аналізованій архітектурі вхідні дані каротажу X перетворюються на матриці Запиту (Q), Ключа (K) і Значення (V) для розрахунку само-

уважності. Зокрема, вхідні дані каротажу X спочатку лінійно відображаються на три матриці: Q, K, V . Ця структура дозволяє нашій архітектурі ефективно опрацювати вхідні сигнали одновимірного каротажу свердловин, демонструючи потужні можливості вилучення ознак і забезпечуючи міцну основу для подальшого вивчення моделі та оптимізації.

$$[Q, K, V] = x[W^Q, W^K, W^V] \quad (5)$$

Навчальна матриця $[W^Q, W^K, W^V]$ обчислює подібність за скалярним добутком QK^T . Ця матриця, важлива для представлення даних і виділення функцій, постійно оновлюється під час навчання для оптимізації виконання завдань. d – розмірність, а d_k запобігає зникненню градієнта під час нормалізації. Отримана матриця уваги $\text{soft max}\left(\frac{QK^T}{\sqrt{d_k}}\right)$ визначає ключові характеристики шляхом аналізу середньозваженого значення з кількох точок даних, що дозволяє отримати ширше та детальніше розуміння вхідних даних.

$$MSA(W^Q, W^K, W^V) = \text{Concat}(\text{Head})W^0$$

$$\text{Head}_i = \text{Atten}(QW_i^Q, KW_i^K, VW_i^V), i = 1, \dots, H \quad (6)$$

Термін *Head* відноситься до різних результатів, отриманих в рамках механізму самоуважності. Крім того, W^0 символізує матрицю параметрів, відповідальну за лінійні перетворення, яка змінює положення кожного елемента вхідної послідовності. Це переміщення передбачає відображення у просторі вищих вимірів, що полегшує більш складне розуміння зв'язків у даних. Конкатенація представлена *Concat*, тоді як багатопаровий перцептрон відіграє вирішальну роль у трансформації ознак і посиленні нелінійності моделі.

$$MLP(x) = FN(\sigma(FN(x))),$$

$$FN(x) = Wx + B. \quad (7)$$

У контексті нейронних мереж W і B позначають компоненти ваги та зміщення повністю зв'язаних шарів відповідно. Тут W працює як матриця перетворення, яка лінійно обробляє виходи з одного шару в новий простір для представлення вхідних даних. Це перетворення передбачає модифікацію та об'єднання кожного виходу в репрезентативний простір через множення на матрицю W . Компонент зміщення, представлений B , є вектором, який вводить додаткові терміни для підвищення адаптивності моделі до різноманітних наборів даних. У архітектурі дані журналу

сегментуються на численні фрагменти з позиційними даними, закодованими та введеними в модель разом із набором даних x .

$$S_0 = [x_{cls}; x_p^1 E; x_p^2 E; \dots; x_p^N E] + E_p,$$

$$S'_l = MSA(LN(S_{l-1})) + S_{l+1}, l = 1, \dots, L, \quad (8)$$

$$S'_l = MSA(LN(S'_l)) + S'_l, l = 1, \dots, L,$$

$$y = LN(S'_l),$$

де E – матриця вкладення, E_p позначає позицію вкладення. Крім того, інтеграція позиції також є невід'ємною частиною обробки даних реєстрації. Нормалізація рівня нормалізує розмірність ознаки кожної вибірки, тобто обчислює середнє значення та стандартне відхилення вздовж розмірності ознаки, а потім централізує та масштабує ознаки кожної вибірки, щоб підтримувати середнє значення 0 і стандартне відхилення 1 для кожного виміру функції.

Стосовно відношення до мета-навчання, то воно представлено підходом у машинному навчанні, що готує моделі до швидкого навчання та адаптації до нових завдань. На відміну від традиційних методів, де моделі пристосовані до конкретних завдань, мета-навчання дає змогу моделям вирішувати різноманітні пов'язані завдання, таким чином дозволяючи їм швидко змінювати свої параметри чи структуру, коли вони стикаються з новими викликами, тим самим підвищуючи їхні можливості узагальнення. Базовими для мета-навчання є дві ключові конструкції: набір підтримки та набір запитів. Набір підтримки формується з компіляції навчальних даних для кількох завдань, де кожне завдання супроводжується відповідним набором вхідних і вихідних даних. Тим часом набір запитів, у якому відсутні вихідні мітки, служить для оцінки ефективності моделі та узагальнення для нових завдань на основі її продуктивності.

Також варте уваги і модельно-агностичне мета-навчання, що представлено як ключова техніка мета-навчання, і призначена для швидкої адаптації до нових завдань шляхом отримання оптимальних початкових параметрів. У аналізованій моделі модельно-агностичне мета-навчання діє як мета-навчання, що допомагає встановити ці початкові налаштування. Це дає змогу нашій архітектурі досягти швидкої конвергенції лише з невеликою кількістю даних. Модельно-агностичне мета-навчання вивчає набір початкових параметрів, що добре адаптуються, і що полегшує точне налаштування моделі на нові завдання, значно скорочуючи

час навчання та вимоги до даних для кожного завдання. Процес оптимізації модельно-агностичного мета-навчання складається з внутрішнього та зовнішнього циклів. У внутрішньому циклі модель вибирає набір завдань із певного набору і обчислює функцію втрат для кожного завдання. Потім модель використовує ці функції втрат для оновлення параметрів для кращої роботи з поточним завданням, подібно до тонкого налаштування кожного завдання для кращої адаптації до його характеристик. У зовнішньому циклі модель використовує оновлення параметрів, отримані з внутрішнього циклу, для оновлення глобальних параметрів моделі. Ці глобальні параметри підсумовують знання та досвід, набуті моделлю в серії завдань, допомагаючи моделі краще адаптуватися до нових завдань. Мета зовнішнього циклу полягає в тому, щоб налаштувати початкові параметри моделі за допомогою мета-навчання, щоб модель могла збігатися та узагальнюватися швидше при зустрічі з новими завданнями. Ключовою перевагою модельно-агностичного мета-навчання є його механізм спільного використання параметрів. У модельно-агностичному мета-навчанні параметри з внутрішнього та зовнішнього циклів є спільними, що означає, що модель може використовувати знання та досвід з інших завдань під час вивчення оновлень параметрів для модельно-агностичного мета-навчання завдання. Цей механізм спільного використання параметрів дозволяє модельно-агностичному мета-навчанню ефективніше використовувати обмежені дані та обчислювальні ресурси, тим самим покращуючи здатність узагальнення та адаптивність моделі. У аналізованій архітектурі застосування модельно-агностичного мета-навчання дозволяє оптимізувати початкові параметри за допомогою мета-навчання, що призводить до швидшої конвергенції та узагальнення для нових завдань. Завдяки модельно-агностичному мета-навчанню аналізована архітектура може швидко адаптуватися до характеристик нових завдань з невеликою кількістю даних і досягати задовільних показників. Цей підхід до мета-навчання забезпечує ефективне рішення для моделей глибокого навчання в умовах дефіциту даних або нових завдань, тим самим стимулюючи застосування та розробку моделей.

У межах мета-навчання набір підтримки має вирішальне значення, оскільки він функціонує як набір даних навчання для конкретних завдань. Цей набір зазвичай містить обмежений масив точок вибіркового даних, кожна з яких містить дані каротажу свердловин у поєднанні з відповідними

літологічними мітками. Обсяг даних у наборі підтримки зазвичай мінімальний, що змушує модель вчитися на цих рідкісних зразках, щоб зрозуміти нюанси завдання. Основна функція набору підтримки полягає в тому, щоб надати моделі важливу інформацію, пов'язану із завданням, дозволяючи їй отримати необхідні знання або стратегії для вирішення завдання. Наприклад, у таких завданнях, як класифікація літології з використанням даних каротажу свердловин, допоміжний набір може включати точки даних з певних геологічних шарів, кожна з яких позначена своєю міткою літології. Завдання моделі полягає в тому, щоб розрізнити характеристики літології з цих даних, що є критичним для точних прогнозів на нових зразках. Складність і велика розмірність даних каротажу свердловин у поєднанні з мізерним розміром вибірки в наборі підтримки вимагають, щоб модель мета-навчання мала надійні можливості навчання для виділення важливих геологічних особливостей з обмежених даних. І навпаки, набір запитів використовується для оцінки здатності моделі до узагальнення щодо конкретного завдання. Він служить доповненням до набору підтримки та зазвичай містить дані каротажу з тих самих класів, які є в наборі підтримки, але отримані з інших зразків. Дані набору запитів не сприяють навчанню, а використовуються виключно для оцінки ефективності моделі для поставленого завдання. Його основна функція полягає в тому, щоб визначити, чи успішно модель навчилася вирішувати завдання за допомогою набору підтримки та чи може застосувати цю навчену здатність до незнайомих даних. Наприклад, у сценарії класифікації літології набір запитів може містити дані каротажу з тих самих геологічних шарів, що й опорний набір, але витягнуті з різних глибин. Модель повинна використовувати інформацію, отриману з набору підтримки, щоб точно класифікувати літологію в наборі запитів, відображаючи її здатність до узагальнення, що є критичним показником адаптивності моделі мета-навчання до нових завдань.

Взаємодія між наборами підтримки та запитів у мета-навчанні відображає взаємозв'язок між наборами навчання та тестування у звичайному машинному навчанні, хоча й з чіткими операційними нюансами. У задачах мета-навчання, які включають дані каротажу свердловин, модель проходить навчання в кількох завданнях, кожне з яких визначається власним набором підтримки, часто отриманим із різноманітних геологічних утворень або регіонів. Набір запитів відіграє вирішальну

роль в оцінці здатності моделі узагальнювати кожне завдання та в наданні зворотного зв'язку для підвищення ефективності майбутніх завдань. Цей циклічний процес навчання та оцінки триває доти, доки модель не продемонструє надійне узагальнення для різноманітних геологічних умов. Кінцевою метою мета-навчання є культивування моделі, яка може швидко адаптуватися до нових завдань, що робить стратегічний дизайн підтримки та наборів запитів життєво важливим для успіху ініціатив мета-навчання. Функція втрат обчислюється окремо для завдань, відібраних із набору завдань, і параметри оновлюються:

$$\theta'_i = \theta - \alpha \nabla_{\theta} L_{\tau_i}(f_{\theta}), \quad (9)$$

де f і θ позначають відповідно модель та її параметр, а α означає внутрішню швидкість навчання. Ця внутрішня швидкість має вирішальне значення в контексті мета-оптимізації, оскільки визначає, як параметри моделі поступово оновлюються під час кожної ітерації.

$$\min_{\theta} \sum_{\tau_i \sim p(\tau)} L_{\tau_i}(f_{\theta_i}) = \sum_{\tau_i \sim p(\tau)} L_{\tau_i}(f_{\theta - \alpha \nabla_{\theta} L_{\tau_i}(f_{\theta})}), \quad (10)$$

де θ , отримані від внутрішньої оптимізації, використовуються для нового завдання або нового зразка. У мета-навчанні модель навчається адаптуватися до різних завдань або зразків. У процесі внутрішньої оптимізації модель коригує свої параметри на основі конкретних завдань або зразків, у результаті чого створюється новий набір параметрів. Потім ці параметри використовуються для обробки нових завдань або зразків. Розрахований градієнт використовується для оновлення початкових параметрів:

$$\theta \leftarrow \theta - \beta \nabla_{\theta} \sum_{\tau_i \sim p(\tau)} L_{\tau_i}(f_{\theta_i}), \quad (11)$$

де β символізує зовнішню швидкість навчання, ключову для оновлення базових параметрів моделі під час мета-навчання, таким чином підвищуючи її адаптивність до нових завдань або зразків. Ця швидкість визначає якість і масштаб оновлення початкових параметрів. Мета-оптимізація, як структурований фреймворк, підтримує швидко адаптацію моделі до нових викликів шляхом вивчення ефективних стратегій навчання. Він охоплює дві ключові фази: внутрішню оптимізацію, яка уточнює параметри для конкретних завдань, і зовнішню оптимізацію, яка оновлює базові параметри, сприяючи швидкій адаптації.

Досліджувана архітектура, як інноваційна візуальна модель, досягла значних результатів на великомасштабних наборах даних. Однак

вона також стикається з деякими проблемами, зокрема структурними зміщеннями, потребою у великих обсягах даних і надмірним використанням пам'яті. Внаслідок цих проблем архітектурі важко виконувати завдання мультикласифікації. Щоб вирішити цю проблему, застосовують епізодичні методи навчання, щоб покращити продуктивність архітектури у сценаріях із кількома кадрами. Досліджувана архітектура не має структурного зміщення, тобто не може використовувати локальну структурну інформацію в зображеннях під час навчання, як традиційні згорткові нейронні мережі. Крім того, архітектура вимагає великих обсягів даних для навчання, щоб повністю вивчити представлення функцій зображень. Через великий розмір моделей архітектурі потрібен значний обсяг пам'яті для зберігання параметрів моделі та обчислення проміжних результатів, що ускладнює застосування архітектури у середовищах з обмеженими ресурсами. Щоб впоратися з цими проблемами, модель вибирає численні другорядні завдання з основного завдання, розділяючи їх на епізоди, що містять декілька зразків. Завдяки ітераційному відбору проб і навчанню модель використовує детальні літологічні характеристики в даних каротажу свердловин, тим самим підвищуючи ефективність навчання. Тим не менш, випадковий характер відбору вибірки в широкому спектрі категорій з обмеженою кількістю вибірок на категорію може призвести до нерівномірного використання вибірки – деяких повторно, а інших – рідко. Ця випадковість може послабити чутливість моделі до розподілу даних певних завдань, потенційно зменшуючи її здатність до узагальнення. Щоб вирішити цю проблему, можна застосувати декілька стратегій для оптимізації процесу відбору та навчання зразків. Наприклад, методи вибірки важливості можна використовувати для коригування ймовірності вибірки на основі важливості вибірок, забезпечуючи їх частішу вибірку. Крім того, методи навчання можна використовувати для поступового введення нових зразків і завдань, що дозволяє моделі динамічно адаптуватися до нових розподілів даних під час процесу навчання. Можна розглянути методи ансамблевого навчання, де передбачення кількох моделей поєднуються для покращення загальної продуктивності моделі. Ансамблеве навчання може зменшити дисперсію моделі, підвищити здатність до узагальнення моделі та краще адаптуватися до різних завдань і розподілу даних. Ці методи можуть допомогти підвищити продуктивність архітектури у не-

ликих задачах мультикласифікації, дозволяючи більш широко застосовувати моделі аналізованої архітектури.

Вирішення складних проблем мультикласифікації кількох кадрів часто передбачає використання епізодичного навчання та методів пакування, обидва відомі тим, що підтримують узагальнення та стабільність моделі, особливо в умовах обмежень даних. Епізодичне навчання передусім передбачає випадковий вибір підмножин із набору метаданих для кожної ітерації навчання, побудову невеликих завдань, що складаються з кількох підвбірок. Цей метод не тільки оптимізує використання літологічних даних для підвищення ефективності навчання, але також плавно інтегрується з мета-навчанням, щоб пришвидшити конвергенцію моделі за допомогою кращих початкових налаштувань параметрів. І навпаки, пакування, метод ансамблю, створює кілька моделей шляхом вибірки різних піднаборів даних із основного набору даних, об'єднуючи їхні прогнози для підвищення загальної точності моделі. Цей метод зменшує дисперсію та підвищує стабільність, будучи особливо корисним у сценаріях дефіциту даних. Ці стратегії, коли вони використовуються в тандемі під час мета-навчання, дають змогу одночасно навчати різні моделі, які разом сприяють кінцевим результатам прогнозування. На етапі тестування використовується ансамблевий підхід шляхом зваженого на основі прогнозів цих моделей. Метод доповнюється вибіркою на основі результатів, що підходить для сценаріїв із кількома кадрами, покращуючи використання даних. Прогнози нормалізуються з використанням механізму нормалізації, при якому класифікаційний вклад кожної моделі зважується та агрегується для визначення остаточної категорії.

$$\tilde{M}(x) = \sum_{r=1}^m \omega_r M_r(x), \quad (12)$$

де ω_r – вага окремої моделі M_r .

У проблемах класифікації потрібно, щоб передбачений моделлю розподіл ймовірностей був схожий на справжній розподіл міток, а функція втрат крос-ентропії точно вимірювала цю невідповідність. Мінімізуючи втрату перехресної ентропії, модель може вивчати точніші межі класифікаційних рішень, таким чином підвищуючи точність класифікації. Використовується адаптивний алгоритм оптимізації швидкості навчання.

Інструменти для каротажу збирають дані про такі властивості, як швидкість звуку та щільність на різних глибинах, які використовуються

для ідентифікації типів гірських порід на основі їхніх фізичних характеристик. Ці дані необхідно очистити, стандартизувати та обробити для створення наборів для мета-навчання та мета-тестування. Випадковий вибір часто використовується для створення різноманітних наборів завдань із набору мета-тестування, гарантуючи, що завдання відображають різні реальні умови. Ця різноманітність допомагає оцінити та покращити продуктивність і узагальнення моделі. Побудова цих наборів даних ефективно підтримує вдосконалення методів ідентифікації літології з моделями глибокого навчання, які підвищують точність і надійність у розвідці нафти і газу.

На етапі мета-навчання дані з набору мета-навчання навчають модель, коригуючи параметри на основі розрахованих втрат:

$$\theta'_i = \theta - \alpha \nabla_{\theta} L_{\tau_i}(f_{\theta}) \quad (13)$$

Набір підтримки, фундаментальний у мета-навчанні, використовується для навчання допоміжної мета-моделі, яка, у свою чергу, уточнює початкові параметри моделі аналізованої архітектури без безпосередньої обробки завдань. Ця підготовка передбачає тестування з набором запитів – ще одним ключовим компонентом мета-навчання, спрямованого на оцінку продуктивності моделі. Початкові параметри моделі досліджуваної архітектури корегують на основі відгуків про продуктивність:

$$\theta \leftarrow \theta - \beta \nabla_{\theta} \sum_{\tau_i \sim p(\tau)} L_{\tau_i}(f_{\theta_i}) \quad (14)$$

Щоб перевірити метод, використовується набір мета-тестування. Спочатку модель проходить доопрацювання з комплектом підтримки, що підвищує її адаптацію до конкретних завдань. Потім набір запитів оцінює свою точність і узагальнення в розпізнаванні літології. Цей розподіл на два набори життєво важливий для оцінки продуктивності, з функціями моделі налаштування набору підтримки та набором запитів, які перевіряють його застосовність. Застосовуючи зважене підсумовування кількох результатів моделі, покращується стабільність і точність моделі, завершуючись надійним остаточною результатом розпізнавання літології, який використовує дані з набору мета-тестування.

Висновки. У рамках запропонованого дослідження було сформовано новий підхід до ідентифікації літології порід, що поєднує у собі вейвлет-аналіз та механізми машинного навчання. Додатково запропонована методика також була покращена шляхом інтеграції мета-навчання, що дозволяє досягти високої точності прогнозування

літологічних характеристик на основі обмежених каротажних даних. Виконане удосконалення алгоритму навчання через використання новітніх технік, таких як агностичне мета-навчання для швидкої адаптації моделей та розроблені епізодичні стратегії, надають моделі більшу адаптивність до нових геологічних умов оптимізуючи процес автоматизованої обробки даних. Подальше удосконалення запропонованих рішень може вклю-

чати автоматичний вибір параметрів вейвлетів та покращення процесів передобробки даних, що дозволить значно підвищити ефективність класифікації літологічних типів. Результати цього дослідження надають основу для інтеграції розроблених методів у практику геологічної розвідки, зокрема в нафтовій та газовій промисловості України, сприяючи зниженню ризиків та витрат у процесах розвідки.

Список літератури:

1. Zhang Y., Xu B., Zhao T. Convolutional multi-head self-attention on memory for aspect sentiment classification. *IEEE/CAA Journal of Automatica Sinica*, vol. 7, no. 4, July 2020, pp. 1038–1044. DOI: <https://doi.org/10.1109/JAS.2020.1003243>
2. Gaudart J., Giusiano B., Huiart L. Comparison of the performance of multi-layer perceptron and linear regression for epidemiological data. *Comput. Stat. Data Anal.*, 44 (4) (2004), pp. 547–570. DOI: [https://doi.org/10.1016/S0167-9473\(02\)00257-8](https://doi.org/10.1016/S0167-9473(02)00257-8)
3. Su J., Ahmed M., Lu Y., Pan S., Bo W., Liu Y. Roformer: enhanced transformer with rotary position embedding. *Neurocomputing*, Volume 568, 2024, Article 127063. DOI: <https://doi.org/10.1016/j.neucom.2023.127063>
4. Xu Z., Chen X., Tang W., Lai J., Cao L. Meta weight learning via model-agnostic meta-learning. *Neurocomputing*, Volume 432, 2021, pp. 124–132. DOI: <https://doi.org/10.1016/j.neucom.2020.08.034>
5. Sadiq and N. Yahya. Fractional Stochastic Gradient Descent Based Learning Algorithm For Multi-layer Perceptron Neural Networks. *2020 8th International Conference on Intelligent and Advanced Systems (ICIAS)*, Kuching, Malaysia, 2021, pp. 1–4. DOI: 10.1109/ICIAS49414.2021.9642687
6. Yang L., Dang B., He Y., Cai C. Research on a Drilling Parameter Prediction Model Based on a Hybrid Model of Multi-Layer Perceptron (MLP) and Convolutional Neural Network (CNN). *2024 6th International Academic Exchange Conference on Science and Technology Innovation (IAECST)*, Guangzhou, China, 2024, pp. 1815–1820. DOI: <https://doi.org/10.1109/IAECST64597.2024.11117890>
7. Said Hassaan, Abdulaziz Mohamed, Ahmed Farid Ibrahim, Salaheldin Elkatatny. Real-Time Prediction of Petrophysical Properties Using Machine Learning Based on Drilling Parameters. *ACS Omega*, volume 9, number 15, pp.17066–17075, 2024. DOI: <https://doi.org/10.1021/acsomega.3c08795>
8. Shahani N.M., Zheng X., Wei X, Hongwei J. Hybrid machine learning approach for accurate prediction of the drilling rate index. *Sci Rep* 14, 24080 (2024). DOI: <https://doi.org/10.1038/s41598-024-75639-z>
9. Xu Zhixiong, Li Ailing, Guo Zongming, Zhao Zhiruo, Qi Qianrui, Chen Xiliang. Rapid Learning of Complex Control Tasks based on Online Optimization Meta-Learning. *KSII Transactions on Internet and Information Systems*. Open Access, volume 19, issue 7, 2025, pp.2140–2156. DOI: <https://doi.org/10.3837/tiis.2025.07.002>
10. Sun Youzhuang, Pang Shanchen, Qiu Zhihan, Zhang Yongan. Efficient lithology classification from small-sample well logging data processed by wavelet thresholding algorithm: Integrating meta-learning with self-attention mechanism model. *Geoenergy Science and Engineering*, volume 246, 2025. DOI: <https://doi.org/10.1016/j.geoen.2024.213629>

Petryshyn R.I. IDENTIFICATION OF ROCK TYPES BASED ON WAVELET ANALYSIS AND MACHINE LEARNING

The scientific study considers and proposes an integrated approach to automated identification of rocks lithology based on input logging data, which allows combining modified wavelet threshold denoising and meta-learned architecture. Proposed in the study, methodology is aimed at improving the quality and accuracy of lithological type classification processes under conditions of limited core and logging samples, presenting key aspects of preliminary signal analysis, scale-dependent threshold selection, and adaptive model optimization. The scientific research presents and justifies the implementation of a double modified threshold function with upper and lower thresholds and scale normalization of wavelet decomposition coefficients in order to reduce reconstruction artifacts and accumulate significant geological features in high-frequency components. The scientific work investigates the criteria for selecting a wavelet basis (symmetry, regularity, and autocorrelation) and provides recommendations for optimal decomposition levels within logging signals, taking into account the properties of heterogeneity and noise.

The modeling processes are represented by adapting the visual data processing architecture to one-dimensional logging sequences, namely, segmenting the input data into patch windows, multidimensional embedding, positional depth encoding, and matrix computation for the self-attention mechanism in the context

of a deep learning model. To overcome the limitations of deep learning models when working with small samples, the study proposes a combination of learning goals and episodic training strategies, which will allow training initial parameters that must adapt as quickly as possible to new and constantly changing geological conditions with a minimum number of samples. In addition, it is also recommended to use episodic task formation and the method of statistical evaluation of mathematical integrals by sampling based on weighting coefficients, which is compensated by the difference between the target and proposal distributions to ensure uniform representation of classes and reduce training variability.

The study analyzes and explores the training and validation procedure in the form of support and query set formation, internal and external optimization cycles with different training speeds, evaluation through a set of meta-tests, and accumulation of predictions using a combination of models with exponential normalization as a way to convert the output values of the models into probabilities before comparison, analysis, combination, and final prediction. The proposed scheme combines wavelet preprocessing and meta-adaptation to achieve cost-effective prediction of lithological processes in the absence of core data, which will ensure a balance between the signal-to-noise ratio and the root mean square error of reconstruction.

The practical value of the proposed approach consists in increasing the accuracy of classification, reducing drilling risks, and optimizing the resource costs of hydrocarbon exploration. In addition, directions for further improvement are outlined based on automatic threshold selection on a scale, optimization of the wavelet basis through cross-validation, and expansion of combined strategies to improve model stability and generalization.

Keywords: *architecture, wavelet analysis, machine learning, automation, meta-optimization, meta-learning, forecasting, models, lithology, logging, geological features.*

Дата першого надходження статті до видання: 15.01.2026

Дата прийняття статті до друку після рецензування: 20.02.2026

Дата публікації (оприлюднення) статті: 08.04.2026